下载APP

22 | 模型稳定性评估：如何用PSI来评估信用评分产品的稳定性?

2021-02-08 刘海丰

成为AI产品经理 进入课程 >

讲述：刘海丰
时长 09:41 大小 8.90M

你好，我是海丰。

模型稳定性指的是模型性能的稳定程度，只有稳定性足够好的模型才能通过上线前的评估，而且上线后，我们也要对模型稳定性进行观测，判断模型是否需要迭代。在实际工作中，我们会用 PSI 来评估模型的稳定性。

这节课，我们就借助一个信用评分的产品，来详细说一说 PSI 是什么，它该怎么计算，以及它的评估标准。

案例：客群变化对模型稳定性的影响

在金融风控领域，稳定性对于风控模型来说就是压倒一切的条件。模型只有足够稳定，才能既通过上线前层层的验证和审批，又能在上线后运行足够长的时间。但在实际工作中，像客群变化这类无法避免的情况，往往会直接影响模型的稳定性。

比如说，在模型上线时候，前端流量有 5000 的测试用户，模型输出的分布可能是下面这样的。如果业务设置阈值为 60 分，那么，60 分以下的人我们会拒绝放款。这样一来，模型会拒绝掉大概 20% 的人，这种情况对于业务来说是可以接受的。

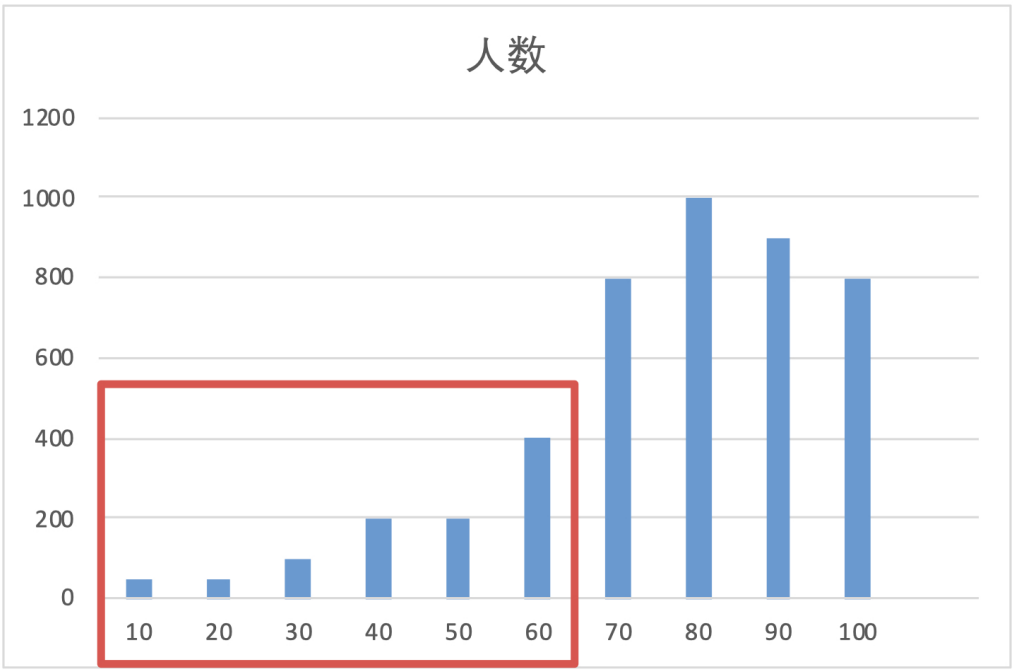

极客时间

如果模型上线后，前端流量没有发生变化，还是 5000 个待测用户，但是客群发生了变化，从测试用户变成了线上的用户。这个时候，模型输出的分布就会变成下面这样。

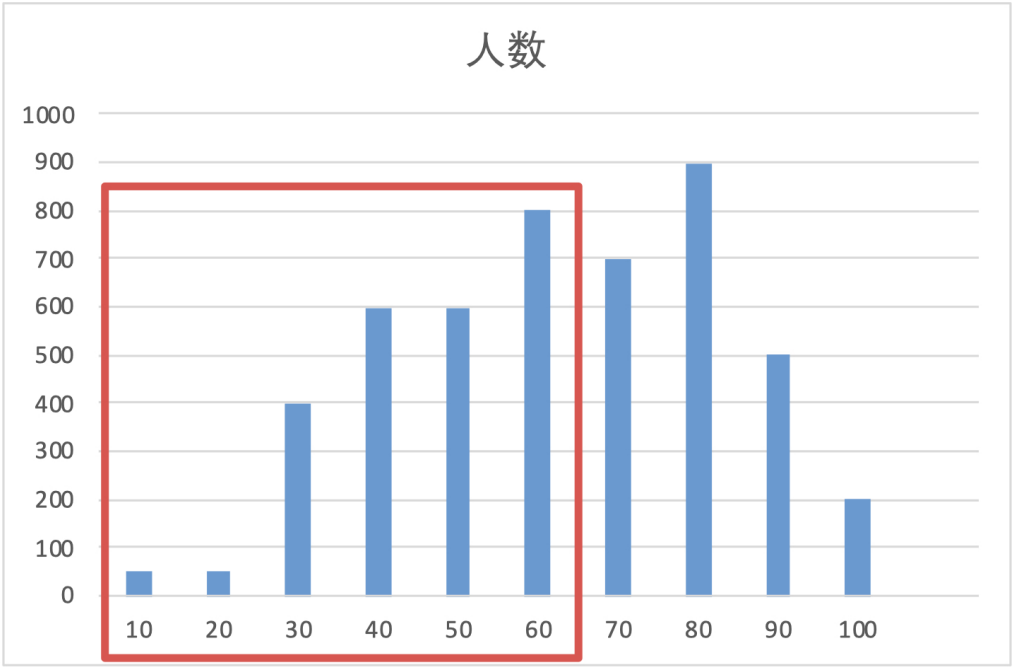

极客时间

如果我们还是用 60 作为阈值，模型就会拒绝掉 50% 的用户。当前市场下，前端流量这么贵，如果风控拒绝了 50% 的用户申请，估计市场或者运营的同学，肯定不会放过风控部门了。

在实际工作中，这种情况的发生就是因为模型不稳定。为了避免这种情况的发生，我们必须要在上线前对模型的稳定性进行评估，尤其是在类似金融风控这类对模型稳定性要求高的场景中。

那么，在上线前，我们该怎么使用 PSI 对模型稳定性进行评估呢？

PSI 指标该如何计算？

首先，我们来看看 PSI 是什么。

所谓 PSI 指标就是群体稳定性指数（Population Stability Index），**通过 PSI 指标，我们可以得到不同样本（不同时间段给到模型的样本）下，模型在各分数段分布的稳定性。**

PSI 的计算公式

我们知道，稳定性是一个相对的概念，只有通过对比，我们才能知道模型是不是稳定。所以，想要计算模型的稳定性，我们需要先有一个参照物。在信用评分模型中，为了进行对比，我们至少需要两个分布结果，一个是预期分布结果一个是实际分布结果。

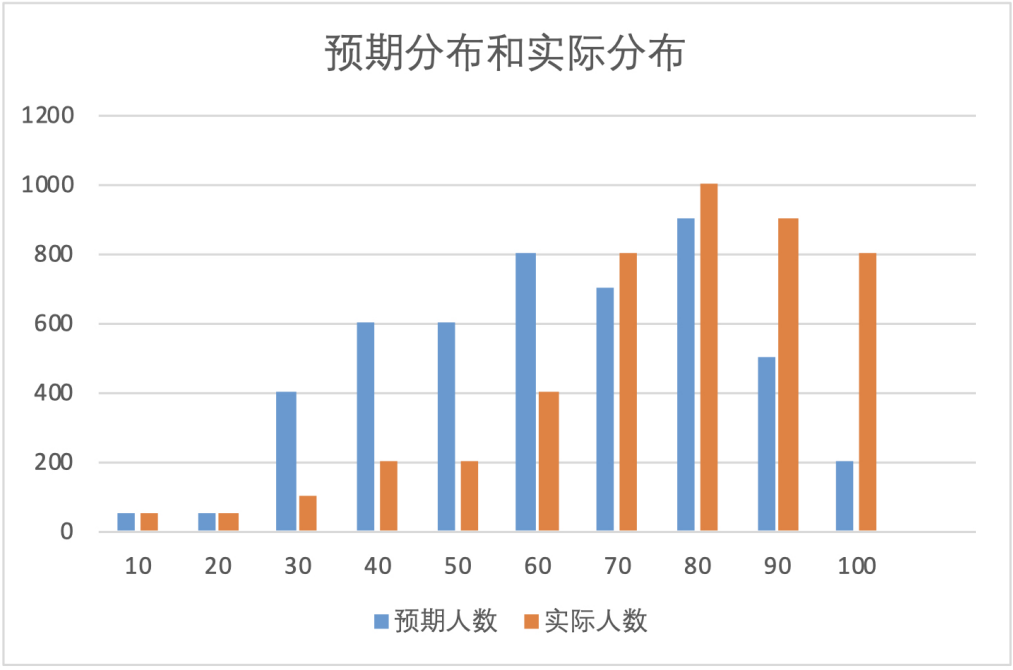

极客时间

在产品验收阶段，我会使用模型上线时的 OOT 样本作为预期样本，非 OOT 时段的近期抽样样本作为实际样本。不仅产品经理，算法工程师也需要对模型的稳定性进行评估，他们通常会在模型验收之前，使用验证样本作为实际分布，使用训练样本作为预期分布，这一点你知道就可以了。

我们期望的是，模型在遇到不同时间段样本的时候，每个分数段的人群占比不要发生太大变化。为了更直观看到预期分布和实际分布的这种变化，我们可以把人数分布直接转化为占比分布。

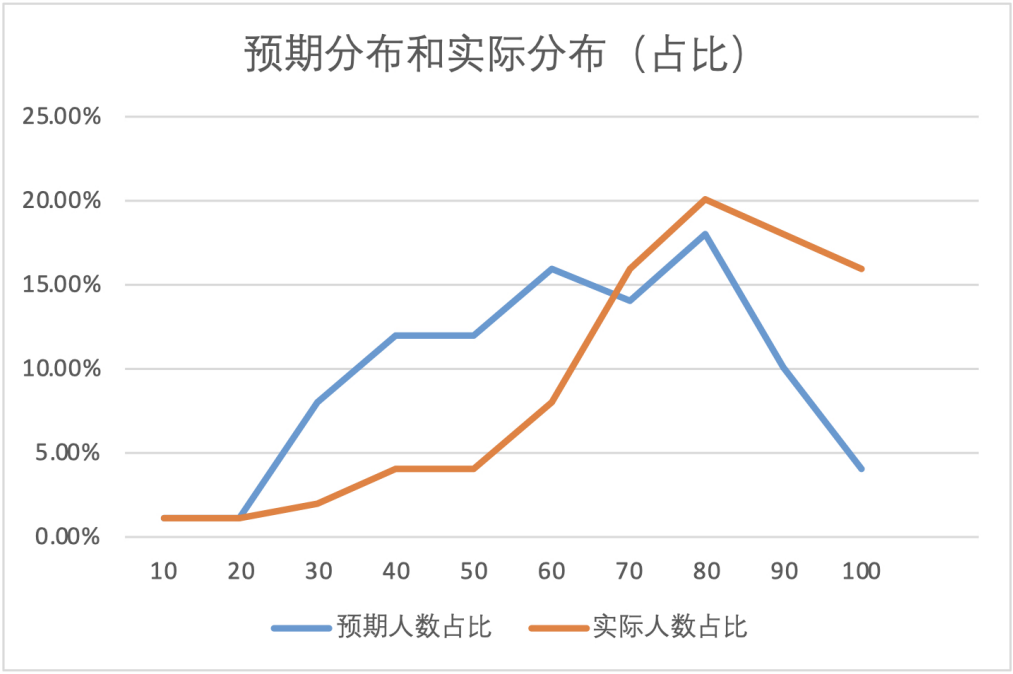

极客时间

通过这张图，我们肉眼就可以看到，在这个模型中，两个不同人群的占比发生了很大的变化。那么，我们该怎么去量化这个变化呢？这个时候就需要用到 PSI 指标了，它的公式是：PSI = SUM (实际占比 - 预期占比) * ln (实际占比 / 预期占比)。

已知，这个信用评分产品的分数范围是 [0, 100]，分数越高说明用户的信用越好。接下来，我们来计算一下这个信用评分产品的 PSI。具体来说，我们可以分三步来操作，分别是分箱、计算实际分布、计算 PSI 数值。

第一步：分箱

由于信用分数是一个个连续值，实际操作中我们不可能对每一个分数点进行测试，因此，我们需要将变量的预期分布进行分箱操作，然后统计每个分箱里面样本的占比。**分箱的方式有两种，一种是等频分箱，另一种是等距分箱。分箱方式不同，模型计算的结果也会有略微的差异。**

那么，什么是等频分箱和等距分箱呢？所谓等频分箱是指每个分箱中的样本数量相等，分数段不同，并且分数段是根据人数占比计算得到的。比如，对于把信用评分的结果，我们使用等频分箱的方式可以把它们分为 10 个箱子。其中，每个箱子分数段不同，但是里面的人数相同，示例如下：

分数	人数	占比
0–30	100	10%
30–45	100	10%
45–59	100	10%
59–63	100	10%
63–65	100	10%
65–70	100	10%
70–73	100	10%
73–80	100	10%
80–90	100	10%
90–100	100	10%

极客时间

等距分箱指的是每个分箱中分数段相同，人数不同，人数是按照分数平均切分的。比如说，对于信用评分结果，我们使用等距分箱把它也分为 10 个箱子，那每个箱子中的分数段相同，但是里面的人数不同，大致样例如下：

分数	人数	预期占比
0–10	20	2.00%
10–20	20	2.00%
20–30	50	5.00%
30–40	80	8.00%
40–50	100	10.00%
50–60	200	20.00%
60–70	200	20.00%
70–80	150	15.00%
80–90	100	10.00%
90–100	80	8.00%

极客时间

因为 PSI 看的是分数段中人数波动情况，所以这里我们选择对预期分布进行等距分箱，也就是上面的分箱方式。

第二步：计算实际分布

我们知道，PSI 比较的是预期分布和实际分布，而模型上线前我们就已经有了预期分布（我习惯使用算法进行 OOT 测试时候得到模型分布数据，当然你也可以选择其他样本作为预期分布），并且我们也已经对数据完成了分箱。接下来，我们需要选择进行测试的样本，把样本传入模型得到实际测试结果，即所有测试用户的信用分数。然后，我们再根据上一步选择的分箱方式，将实际测试结果同样进行分箱，计算分箱后的占比。一般来说，测试样本距离当前日期越近越好。

分数	人数	实际占比
0–10	15	1.50%
10–20	22	2.20%
20–30	35	3.50%
30–40	70	7.00%
40–50	110	11.00%
50–60	210	21.00%
60–70	198	19.80%
70–80	160	16.00%
80–90	110	11.00%
90–100	70	7.00%

极客时间

第三步：计算 PSI

完成分箱，计算出实际分布之后，我们就可以利用公式计算 PSI 了。为了方便计算和查看，我们将前两步的结果整合到一张表格中。

分数	人数	实际占比
0–10	15	1.50%
10–20	22	2.20%
20–30	35	3.50%
30–40	70	7.00%
40–50	110	11.00%
50–60	210	21.00%
60–70	198	19.80%
70–80	160	16.00%
80–90	110	11.00%
90–100	70	7.00%

极客时间

以第一行的分数段 [0,10]为例，我们先计算实际占比 - 预期占比 = 1.5%-2% = -0.5%，然后计算实际占比 / 预期占比 = 1.5% / 2% = 75%，之后计算 ln (实际占比 / 预期占比) = -0.28768。最后是计算 index = (实际占比 - 预期占比) * ln (实际占比 / 预期占比) = -0.5% * -0.28768 = 0.0014。

接下来，我们分别计算其余 9 组分箱的 index 值，最后可以得到下表的数据：

序号	分数	预期占比	实际占比	实际占比-预期占比	实际占比/预期占比	ln(实际占比/预期占比)	index
1	0–10	2.00%	1.50%				
2	10–20	2.00%	2.20%				
3	20–30	5.00%	3.50%				
4	30–40	8.00%	7.00%				
5	40–50	10.00%	11.00%				
6	50–60	20.00%	21.00%				
7	60–70	20.00%	19.80%				
8	70–80	15.00%	16.00%				
9	80–90	10.00%	11.00%				
10	90–100	8.00%	7.00%				

极客时间

根据公式，最终的 PSI 值就是表格每一个分箱的 index 求和：PSI=sum(index1+index2+...+index10) = 0.0127。

以上就是 PSI 指标的计算过程了。但是，得到 PSI 之后，我们怎么利用它对模型稳定性进行评估呢？我们得到的数字又代表什么业务含义呢？

在业务层面，PSI 数值越小说明两个分布之间的差异也就越小，也就代表模型越稳定。更具体一点，我们一般会这么定义模型的稳定性：

PSI范围	稳定性	备注
0–0.1	好	分布变化小，我们无需关注
0.1–0.25	一般	分布发生变化，需要我们后续持续监控
0.25以上	不稳定	分布发生比较大的变化，需要算法工程师进行特征分析或者重新调整模型

极客时间

小结

PSI 的计算过程非常简单，在工作中我们也不需要手工去计算 PSI，通过 Python 代码就可以直接计算。今天，我希望你能通过它的计算过程深入理解它的原理。

首先，PSI 指的是群体稳定性指数，它可以表示不同样本下模型的稳定性。稳定性是一个相对的概念，在信用模型中，我们会使用至少两类分布结果进行判断，分别是预期分布结果和实际分布结果。这其中，计算 PSI 的目的，就是为了判断实际分布和预期分布相比是否存在比较大的变化。

那在实际计算 PSI 的时候，我们会通过三步来进行，分别是分箱、计算实际分布和计算 PSI。其中，分箱是一个非常常见和重要概念，不仅是在计算 PSI 的时候，在对其他指标进行评估的时候，我们也会借助分箱的方式，来帮助我们处理数据。

至于利用 PSI 对模型进行评估就非常简单了，总的来说就是 PSI 数值越小，两个分布之间的差异也就越小，模型越稳定。PSI 的值在 0.1-0.25 之间，都是可以接受的范围。

除此之外，在实际工作中使用 PSI 的时候，我还有 3 点建议提供给你。

1. PSI 值不应该只是在模型上线时候关注，在上线后我们也要持续关注。因为客群必然会随着时间的推移发生变化，这会导致人群分布发生变化，而且这个变化会越来越大，从而影响模型的预测能力。
2. 影响 PSI 的变化因素很多，常见的有客群变化（尤其是互金市场用户群体变化很快）、数据源变化（外部接入的数据源停用或者效果下降）等等。
3. 上线后，为了能够随时关注模型稳定性的情况，我建议你根据业务场景对模型稳定性的要求，对模型 PSI 进行按日、按月或者按季度监控。

课后讨论

今天的最后，我还想请你思考一个问题，我们今天说了 PSI 指标是为了衡量两个分布之间的差异，它的公式是：SUM（实际占比 - 预期占比）* ln（实际占比 / 预期占比）。那么，为什么公式需要增加“ ln（实际占比 / 预期占比）”部分，而不是直接使用：SUM（实际占比 - 预期占比）呢?

期待在留言区看到你的思考和答案，我们下节课见！

提建议

更多课程推荐

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 21 | 模型性能评估（三）：从股价预测产品看回归算法常用的评估指标

下一篇 23 | 模型监控：产品经理如何建设算法模型监控指标体系？

精选留言 (1)

写留言

金鱼
2021-02-08

在占比都比较小的情况下，采用比较后取对数，可以在消除量纲的前提下，将差别放大。作为系数乘以差值，将差异放大。

展开